

Teoretyczne podstawy informatyki

Andrzej M. Borzyszkowski

Instytut Informatyki
Uniwersytet Gdański

sem. letni 2025/26

inf.ug.edu.pl/~amb/TPI

Andrzej M. Borzyszkowski (Instytut Informatyki) Teoretyczne podstawy informatyki sem. letni 2025/26 1 / 13

Wykład 06 Podstawienia i homomorfizmy

Podstawienie

- dany alfabet A i język $L \subseteq A^*$
- dany być może inny alfabet Σ i dla każdej litery $a \in A$ język $L_a \subseteq \Sigma^*$
- dla słowa $u \in A^*$ definiujemy język $L_u = L_{u_1} \cdot \dots \cdot L_{u_\ell}$
- dla całego języka L definiujemy $\text{subs}(L) = \bigcup_{u \in L} L_u$
- tw. jeśli L i wszystkie języki L_a są bezkontekstowe, to $\text{subs}(L)$ jest językiem bezkontekstowym nad Σ
- dw.: możemy założyć, że zmienne gramatyk dla L i L_a są rozłączne
 - symbolem początkowym będzie symbol początkowy dla L
 - jeśli w produkcji gramatyki dla L występuje symbol terminalny $a \in A$, zastępujemy go symbolem początkowym S_a języka L_a
 - symbolami końcowymi będzie zbiór Σ
 - konstrukcja analogiczna do języków regularnych – wystąpienie a w słowie nie kończy produkcji, jest kontynuowane w kolejnym języku

Andrzej M. Borzyszkowski (Instytut Informatyki) Teoretyczne podstawy informatyki sem. letni 2025/26 3 / 13

Dalsze operacje na językach bezkontekstowych

Andrzej M. Borzyszkowski (Instytut Informatyki) Teoretyczne podstawy informatyki sem. letni 2025/26 2 / 13

Wykład 06 Podstawienia i homomorfizmy

Podstawienie, przykład

- dane języki bezkontekstowe L_a i L_b
rozważmy języki nad $\{a, b\}$: $L_{\text{sum}} = \{a, b\}$, $L_{\text{konk}} = \{ab\}$,
 $L_{\text{iter}} = \{a^n \mid n \in \mathbb{N}\}$
- podstawienie $a \mapsto L_a$, $b \mapsto L_b$ zastosowane do powyższych języków prowadzi do $L_a \cup L_b$, $L_a L_b$, L_a^*
- czyli dowód, że klasa języków bezkontekstowych jest zamknięta na sumę, konkatenację i iterację jest wnioskiem z twierdzenia o podstawieniu

Andrzej M. Borzyszkowski (Instytut Informatyki) Teoretyczne podstawy informatyki sem. letni 2025/26 4 / 13

Homomorfizm

- homomorfizm $h : A \rightarrow \Sigma^*$ to szczególne podstawienie $L_a = \{h(a)\}$ będziemy automatycznie przedłużać na słowa, $h : A^* \rightarrow \Sigma^*$,
 $h(u) = h(u_1) \dots h(u_\ell)$
- tw.: obraz i przeciwobraz języka bezkontekstowego jest językiem bezkontekstowym
 - dw.: obraz: było przed chwilą
 - przeciwobraz: dowód jest znacznie bardziej złożony niż dla języków regularnych, idea jest podobna
 w automacie ze stosem rozpoznającym język nad Σ definiujemy przejścia etykietowane symbolami z A analizując ruchy automatu przy wejściu $h(a)$
 konieczne jest zadbanie o prawidłową obsługę stosu, co jest możliwe, szczegóły pomijamy

Algorytmy decyzyjne

Podstawienia i homomorfizmy dla języków klasy DPDA

- tw.: przeciwobraz języka rozpoznawanego przez DPDA należy do tej samej klasy
 - dw.: w dowodzie budowany jest nowy automat, jeśli oryginalny był deterministyczny, to nowy też będzie
- tw.: obraz przy homomorfizmie języka rozpoznawanego przez DPDA nie należy do tej klasy, podstawienie również
 - dw.: założmy, że dane są dwa języki L_i nad alfabetem $\{a, b\}$, suma $1L_1 \cup 2L_2$ jest językiem nad $\{1, 2, a, b\}$ rozpoznawanym przez DPDA; homomorfizm $1 \mapsto 2$ skleja pierwsze litery i obraz $2L_1 \cup 2L_2$ nie musi być rozpoznawany
 - ten sam pomysł L_1 i L_2 pokazuje, że konkatenacja z 1^* nie jest klasy DPDA

Problemy dotyczące języków

- dane języki $L, L_1, L_2 \subseteq A^*$, słowo $w \in A^*$, możemy postawić pytania
 - czy język $L \neq \emptyset$, jest niepusty?
 - czy język $|L| < \infty$, jest skończony?
 - czy $L_1 = L_2$, języki są równe?
 - ogólniej, czy $L_1 \subseteq L_2$?
 - czy $w \in L$, słowo należy do języka?
- oprócz samej odpowiedzi interesuje nas też algorytm o jak najmniejszej złożoności
- odpowiedzi zależą od
 - klasy języków: regularne, bezkontekstowe, inne klasy
 - sposobu zdefiniowania języka: automat deterministyczny, niedeterministyczny, gramatyka, w jednej z postaci normalnych

Problem pustości języka $L = \emptyset$?

- język regularny dany jest automatem deterministycznym lub nie, zaakceptowane słowo wyznacza ścieżkę od stanu początkowego do akceptującego
 - czyli wystarczy wykonać algorytm szukania ścieżki w grafie, np. wgłąb, i sprawdzić, czy znajdziemy stan akceptujący na końcu ścieżki, niedeterminizm automatu w niczym nie przeszkadza
 - dla wyrażenia regularnego można łatwo zbudować automat
 - alternatywnie gwarancję niepustości daje ϵ lub dowolna litera alfabetu w wyrażeniu i można przeanalizować całość
- język bezkontekstowy dany jest gramatyką
 - algorytm usuwania zbędnych symboli nieterminalnych albo pokaże, że nie ma żadnych produkcji albo udowodni, że język jest niepusty
 - język zdefiniowany automatem ze stosem wymaga zbudowania gramatyki, koszt może być nietrywialny ale jest wielomianowy

Problem przynależności słowa $w \in L$?

- jeśli język regularny dany jest automatem deterministycznym, wystarczy wykonać automat na słowie w
 - jeśli automat definiujący jest niedeterministyczny, po odczytaniu każdej litery słowa trzeba rozpatrywać możliwe stany automatu, złożoność mniejsza niż determinizacja całości
 - jeśli język definiowany jest wyrażeniem regularnym, to daje ono automat niedeterministyczny i dalej j.w.
- dla języka definiowanego gramatyką bezkontekstową można stosować naiwny algorytm, w którym wykonujemy obliczenia automatu ze stosem testując wszystkie możliwe produkcje przy odczycie każdej litery
 - zdecydowanie lepszą złożoność $O(n^3)$ ma algorytm CYK (Cock-Younger-Kasami)
 - niektóre gramatyki gwarantują mniejszą złożoność tego algorytmu

Problem skończoności języka $|L| < \infty$?

- język regularny dany jest automatem, zaakceptowane słowo wyznacza ścieżkę od stanu początkowego do akceptującego
 - język ma nieskończenie wiele słów w.t.w. na jakiejś ścieżce istnieje cykl (lemat o pompowaniu)
 - wyrażenie regularne można przekształcić w automat
 - można też analizować wyrażenie, źródłem nieskończoności jest operator Kleene'go ale stosowany do podwyrażenia niepustego
- język bezkontekstowy zdefiniowany gramatyką Chomsky'ego
 - produkcja $A \rightarrow BC$ buduje krawędzie $A \rightarrow B$, $A \rightarrow C$ w grafie symboli nieterminalnych
 - tw: język jest nieskończony w.t.w. istnieje cykl osiągalny z symbolu początkowego
 - dw.: dość oczywisty

Algorytm CYK

- problem: dana gramatyka bezkontekstowa w postaci Chomsky'ego (tzn. produkcje są postaci $A \rightarrow BC$ lub $A \rightarrow a$), sprawdzić czy słowo $w = w_1 \dots w_n$ jest generowane przez tę gramatykę
- budujemy dwuwymiarową macierz CYK
 - w komórce $CYK[i, j]$ są zmienne gramatyki generujące pod słowo długości i zaczynające się w miejscu j , $w_j \dots w_{j+i-1}$
 - dla $i = 1$ mogą być użyte jedynie produkcje $A \rightarrow a$
 - gdy słowa długości $< m$ zostały rozpatrzone, sprawdzamy, czy $B \in CYK[k, j]$, $C \in CYK[m-k, j+k]$ oraz $A \rightarrow BC$ jeśli tak, to $A \in CYK[m, j]$ – generuje słowo długości m w miejscu j
 - $w \in L$ w.t.w. $S \in CYK[n, 1]$
- jest $O(n^2)$ komórek w macierzy, każdą wypełniamy kosztem $O(n)$
- złożoność $O(n^3)$

Algorytm CYK, przykład $(2 + 3) * 5$

- gramatyka wyrażeń arytmetycznych w postaci Chomsky'ego

 $W \rightarrow 0 \mid \dots \mid 9 \mid (P \mid SR \mid WT$ wyrażenie

 $P \rightarrow W)$ reszta nawiasu

 $R \rightarrow *C$ reszta mnożenia

 $T \rightarrow +S$ reszta dodawania

 $S \rightarrow 0 \mid \dots \mid 9 \mid (P \mid SR$ składnik

 $C \rightarrow 0 \mid \dots \mid 9 \mid (P$ czynnik

- macierz CYK

	1	2	3	4	5	6	7
1	(	WSC	+	WSC	)	*	WSC
2			T	P		R	
3		W					
4		P					
5	WSC						
6							
7	WS						